


VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ
BRNO UNIVERSITY OF TECHNOLOGY



**FAKULTA ELEKTROTECHNIKY A KOMUNIKAČNÍCH
TECHNOLOGIÍ**
ÚSTAV AUTOMATIZACE A MĚŘICÍ TECHNIKY

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION
DEPARTMENT OF CONTROL AND INSTRUMENTATION

MĚŘENÍ RYCHLOSTI VOZIDLA

CAR SPEED MEASUREMENT

DIPLOMOVÁ PRÁCE
MASTER'S THESIS

AUTOR PRÁCE
AUTHOR

Bc. Karel Vořechovský

VEDOUCÍ PRÁCE
SUPERVISOR

doc. Ing. Petr Beneš, Ph.D.

BRNO 2011

Bibliografická citace:

VOŘECHOVSKÝ, K. *Měření rychlosti vozidla*. Brno: Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, 2011. 85s. Vedoucí diplomové práce byl doc. Ing. Petr Beneš, Ph.D.

Prohlášení

„Prohlašuji, že jsem svou diplomovou práci na téma Měření rychlosti vozidla vypracoval samostatně pod vedením vedoucího diplomové práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

Jako autor uvedené diplomové práce dále prohlašuji, že v souvislosti s vytvořením této diplomové práce jsem neporušil autorská práva třetích osob, zejména jsem nezasáhl nedovoleným způsobem do cizích autorských práv osobnostních a jsem si plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č. 40/2009 Sb.

V Brně dne: **23. května 2011**

.....
podpis autora

Poděkování

Děkuji vedoucímu diplomové práce doc. Ing. Petru Benešovi, Ph.D. za účinnou metodickou, pedagogickou a odbornou pomoc a další cenné rady při zpracování mé diplomové práce.

V Brně dne: **23. května 2011**

.....
podpis autora

Obsah

1	Úvod	8
2	Popis řešení	9
2.1	Dopplerův jev	9
2.2	Detekce vozidla	10
2.3	Stanovení jeho rychlosti	10
2.4	Vozidlo jako zdroj zvuku	10
2.5	Parazitní jevy	11
3	Dnešní stav	11
3.1	Magnetické – pasivní a aktivní	11
3.2	Pasivní akustické	12
3.3	Aktivní ultrazvukové	12
3.4	Infračervené – pasivní a aktivní	12
3.5	Mikrovlnné	13
3.6	Video	13
3.7	Piezoelektrické, optické a pneumatické kabely	13
3.8	Kombinované	14
4	Měřicí řetězec	16
4.1	Diskuse parametrů měřicího řetězce č.1	19
4.2	Návrh ideálního měřicího řetězce	21
5	Popis algoritmů	22
5.1	Detekce vozidla	23
5.1.1	Detekce vozidla na základě efektivní hodnoty snímaného signálu	23
5.1.2	Detekce vozidla na základě signálového spektra	24
5.1.3	Diskuse obou algoritmů	26
5.2	Analýza frekvenčního spektra signálu	32
5.2.1	Periodogram	32
5.2.2	Metoda minimální variance	34
5.2.3	Parametrické metody	35
5.3	Možnosti sledování frekvence v čase	37
5.4	Optimální metoda pro sledování významné frekvence	39
5.5	Výpočet rychlosti	43
5.6	Implementace algoritmů	46
6	Demonstrace algoritmů	47

7	Provedená měření	55
8	Závěr.....	56

1 ÚVOD

Rozvoj silniční dopravy vede k dokonalejším metodám řízení provozu na dopravních komunikacích. Tímto oborem se zabývá dopravní telematika, která využívá sběr a zpracování dat pro její optimalizaci. Cílem telematiky je zlepšení kvality provozu na dopravních sítích, jako je zvyšování bezpečnosti provozu, efektivnosti dopravy a kapacity na přetížených úsecích, kvality poskytování služeb v dopravě, zmírnění negativních účinků na životní prostředí, snižování časových ztrát způsobených kongescemi. Telematické systémy instalované na dopravních komunikacích nebo ve vozidlech pomáhají řidičům při navigaci, při objíždění úseků s dopravními kongescemi, úseků s dopravními nehodami nebo dopravním omezením. V silniční a dálniční síti systémy dopravní telematiky umožňují kvalitnější řízení dopravy podle aktuálních požadavků, pomáhají detekovat dopravní nehody a následně poskytují informace a instrukce řidiči a tak přispívají ke zvýšení bezpečnosti na silničních a dálničních komunikacích.

Prvky dopravní telematiky jsou velmi účinným nástrojem pro podporu mobility, zvýšení bezpečnosti provozu na pozemních komunikacích a k ochraně životního prostředí na stávajících dopravních sítích.

Základ dopravního telematického systému je tvořen informačními technologiemi, které obsahují informace o jednotlivých prvcích dopravního řetězce a o uživatelích dopravy. Dopravní telematický systém umožňuje sběr, přenos, zpracování a výměnu dat, mezi různými uživateli dopravního řetězce.

Pro zkvalitnění detekce telematických informací je potřeba nacházet nové metody sběru dat, které jsou ekonomicky dostupné pro všechny třídy silničních komunikací.

Cílem této práce je navrhnout a ověřit využití akustických metod pro monitorování silniční dopravy, které doposud nenašly v dopravní telematice širší uplatnění. Využití elektretových mikrofónů, výkonné výpočetní techniky a vhodných algoritmů zpracování dat, které umožní doplnění standardních systémů, levnými zařízeními použitelnými i na komunikacích nižších tříd.


2 POPIS ŘEŠENÍ

Dnes běžně používané telematické systémy vycházejí z koncepce pevně instalovaných systémů pro předem vybrané a schválené místo, ve kterém musí být provedeny příslušné stavební úpravy pro možnost realizace takového systému. Následující návrh předkládá popis telematického prvku, který by nevyžadoval složitou instalaci, byl levný a ekonomicky výhodný pro použití i na silnicích nižších tříd.

Kombinace levného snímače (mikrofonu) společně s levnou výpočetní technikou (PC se zvukovou kartou) vytváří možnost realizovat detektor vozidel, se schopností měřit jejich rychlost, za cenu řádově nižší, než dnes běžně používané telematické systémy, poskytující stejnou nebo podobnou funkcionalitu.

2.1 Dopplerův jev

Jev objevený v roce 1842, jedná se o změnu pozorované frekvence vlnění, kdy se pozorovatel vzhledem ke zdroji vlnění pohybuje. Pohybují-li se vůči sobě zdroj vlnění a pozorovatel, pak při vzájemném přibližování je frekvence přijímaného vlnění vyšší a při vzájemném oddalování nižší. Jev velmi dobře ilustruje . Jsou zde dva pozorovatelé; Martin a Karel. Protože se zdroj vlnění pohybuje směrem od Martina, za každou periodu se zdroj o kousek vzdálí, to znamená, že vlnoplocha pak letí k Martinovi delší dobu, tím se zvyšuje perioda signálu, resp. jeho frekvence. Stejný jev můžeme pozorovat na straně Karla s tím rozdílem, že se perioda signálu zkracuje.



Obrázek 1 - demonstrace Dopplerova efektu

Obecně lze Dopplerův jev formulovat pomocí následující rovnice:

$$f = \left(\frac{c + v_r}{c + v_s} \right) f_0, \quad (1)$$

Za předpokladu, že vozidlo obsahuje akustické zdroje s neměnnou frekvencí z pohledu vozidla, je možné ze znalosti tohoto jevu stanovit rychlost vozidla.

2.2 Detekce vozidla

Pro možnou analýzu akustické stopy, kterou vozidlo vytvoří, je ji třeba časově omezit, tedy určit čas, ve kterém se vozidlo nachází dostatečně blízko pozorovateli (mikrofonu) tak aby byly jeho akustické projevy v signálu rozpoznatelné. Je tedy třeba vozidlo nejdříve detekovat, na základě znalosti jeho akustických projevů.

V této práci je diskutována možnost detekce vozidla na základě změny akustického výkonu (průjezd vozidla je slyšet) a na základě spektra signálu kdy vozidlo je „slyšet“ a kdy není.

2.3 Stanovení jeho rychlosti

Předpokládejme, že vozidlo je zdrojem zvuku o konstantní frekvenci v měřeném úseku a že tento zvuk je dobře „slyšitelný“ po celou dobu průjezdu. Pokud je systém schopen detekovat projíždějící vozidlo, je možné pomocí frekvenční analýzy takového signálu v čase ze znalosti Dopplerova jevu rozhodnout o jeho rychlosti.

2.4 Vozidlo jako zdroj zvuku

Každé pohybující se vozidlo vyzařuje zvuk, který je součtem všech základních akustických zdrojů:

- hluk pohonného ústrojí (motor, převodovka apod.)
- aerodynamický hluk karoserie
- hluk pneumatik odvalujících se po vozovce

2.5 Parazitní jevy

Vyhodnocení měřeného signálu ovlivňují parazitní akustické jevy. Nejvýznamnější jsou změny klimatických podmínek, které ovlivňují šíření zvuku v prostředí (děšť, sníh, silný vítr). Dále všechny akustické zdroje, které jsou zaznamenávány společně s projíždějícím vozidlem a nijak s ním nesouvisí. Pro korektní výsledky je nutné v maximální možné míře tyto parazitní jevy omezit (například akustický kryt mikrofону, vhodné měřicí stanoviště, správně dimenzovaný měřicí řetězec, vhodné algoritmy pro potlačení těchto parazitních jevů při digitálním zpracování signálu).

3 DNEŠNÍ STAV

Systémy pro monitorování dopravy využívají několika možných technologií, díky kterým měří a zaznamenávají různá dopravní data. V této kapitole jsou velmi krátce popsány již používané systémy pro monitorování dopravy.

Princip činnosti

V dnešní době patří mezi nejvíce rozšířené následující systémy.

- magnetické – pasivní a aktivní
- pasivní akustické
- ultrazvukové – pulzní a Dopplerovské
- infračervené – pasivní a aktivní
- mikrovlnné
- video
- piezoelektrické, optické a pneumatické kabely
- kombinované

3.1 Magnetické – pasivní a aktivní

Pasivní magnetické snímače, známé jako „mikro smyčky“ měří změnu v magnetickém poli prostředí vyvolanou průjezdem vozidla detekční zónou (**CITACE**).

Aktivní magnetické snímače, jako jsou indukční smyčky, využívají pro detekci vozidel naladěné RLC obvody, které se přiblížením vozidla rozladí.

Uváděné měřené parametry vozidel: počet, typ, směr jízdy, přítomnost a rychlost v konfiguracích jedné smyčky, nebo dvou v úsekové vzdálenosti vozovky.

Omezení: Tyto snímače se ve většině případů instalují přímo do povrchu vozovky a jsou tak náchylné k poškození, vytržení, nebo přerušení či zkratu měřicího obvodu. Obecně platí, že jejich funkčnost je ovlivněna stavem vozovky, sněh, voda nebo kovové předměty v jejich blízkosti. Jejich instalace je velmi složitá, vyžaduje omezení nebo zastavení provozu, stejně jako jejich oprava a servis.

3.2 Pasivní akustické

Pasivní akustické detekční systémy se sestávají z mikrofonního pole namířeného na dopravní komunikaci. Tyto systémy „naslouchají“ dopravnímu hluku a sledují pohyb jednotlivých akustických zdrojů v mikrofonním poli.

Uváděné měřené parametry vozidel: počet, rychlost, typ a směr jízdy.

Omezení: podnební podmínky, které mají vliv na šíření zvuku; silný vítr, déšť a silné sněžení. Fyzikální podstata šíření intenzity zvuku s kvadrátem vzdálenosti zdroje předurčuje tyto systémy pro měření na krátké vzdálenosti.

3.3 Aktivní ultrazvukové

Pulzní snímače vysílají krátký ultrazvukový pulz a po jeho odrazu zpět do snímače měří dobu jeho letu.

Dopplerovské snímače vysílají nepřetržitý ultrazvukový signál a na základě Dopplerova jevu měří frekvenční posun přijatého signálu.

Uváděné měřené parametry vozidel: Dopplerovské – počet, směr jízdy, rychlost; pulzní – počet, přítomnost, směr jízdy, rychlost a typ.

Omezení: stejně jako u pasivních, pulzní mají problém kvůli omezené rychlosti zvuku s měřením rychlosti u rychle jedoucích vozidel. Dopplerovské - schopnost detekce vozidel pohybujících se nad určitou minimální rychlost.

3.4 Infračervené – pasivní a aktivní

Pasivní infračervené snímače snímají změnu infračerveného záření emitovaného z detekční zóny. Porovnávají infračervené záření vozovky se zářením projíždějícího vozidla. Detekuje se obraz tepelné energie.

Aktivní snímače detekují přítomnost vozidla pomocí vyzaření nízko-energetického laserového pulzu a měří čas jeho návratu zpět ke snímači.

Uváděné měřené parametry vozidel: Pasivní infračervené měří počet, směr jízdy, přítomnost a rychlost; aktivní pak počet, směr jízdy, přítomnost, typ a rychlost.

Omezení: Aktivní snímače jsou obecně omezeny podnebím asi v takovém rozsahu jako je vidění lidského oka; kromě nedostatečného osvětlení.

3.5 Mikrovlnné

Mikrovlnné snímače vysílají nízko-energetický paprsek do místa detekce a na základě Dopplerova jevu analyzují odražený signál.

Uváděné měřené parametry vozidel: počet a rychlost, směr.

Omezení: Schopnost detekce vozidel pohybujících se nad určitou minimální rychlost (rychlost chůze).

3.6 Video

Systémy pro monitorování dopravy pomocí videa využívají pro detekci vozidla změnu obrazové matice a hledání významných charakteristik vozidla (SPZ), pro přesnější okamžik detekce při měření úsekové rychlosti se používají referenční body na vozovce (bílá čára přes vozovku).

Uváděné měřené parametry vozidel: počet, rychlost, přítomnost, směr jízdy, SPZ, typ,..., video systémy vytváří uživatelsky snadno čitelný výstup v podobě fotky.

Omezení: nepřesné nastavení a seřízení systému, špatná viditelnost, obecně jsou limitujícími faktory stejné jako ty, které omezují schopnost člověka vyčíst z videosignálu výše uvedené měřené parametry.

3.7 Piezoelektrické, optické a pneumatické kabely

Piezoelektrické měří piezo-napětí způsobené deformací kabelu při přejezdu vozidla. Optické měří útlum optického signálu v optickém vlákne způsobeným deformací při přejezdu vozidla. Pneumatické měří změnu tlaku uvnitř kabelu při jeho deformaci způsobené průjezdem vozidla.

Uváděné měřené parametry vozidel: počet, rychlost, směr jízdy, přibližně váha a typ; pneumatické pouze počet, rychlost a směr jízdy.

Omezení: životnost deformované části, závislé na kvalitě povrchu vozovky.

3.8 Kombinované

Kombinace výše uvedených technologií je zvlášť užitečná pro sběr dopravních dat. Příkladem je detektor ASIM DT-351 firmy Xtralis. Ten kombinuje pasivní infračervenou detekci vozidel a detekci kolon, společně s Dopplerovým mikrovlnným radarem pro měření rychlosti vozidel.

Uvedené technologie s ukázkovými příklady shrnuje Tabulka 1.

Zařízení	Počet vozidel	Rychlost	Délka vozidla	Přítomnost
Magnetické - aktivní				
Induk. smyčka	X	X	X	X
Magnetické - pasivní				
3M Microloop	X	X	X	X
SPVD	X	X	X	X
Pneu. kabel	X	X	X	-
Pasivní infračervené				
ASIM IR 224	X	-	-	X
ASIM IR 254	X	X	X	X
Eltec M-824	-	-	-	X
Siemens PIR-I	X	-	-	X
Aktivní infračervené				
Autosense II	X	X	X	-
Mikrovlnné – Doppler				
TC 26-B	X	X	-	-
TDN-30	X	X	-	-
Loren	X	X	X	-
Mikrovlnné – detekce přítomnosti vozidla				
Accuwave150LX	X	-	-	X
RTMS	X	X	X	X
Ultrazvukové				
TC-30	X	-	-	X
Lane King	X	-	-	X
Pasivní akustické				

Smartek SAS-I	X	X	X	X
SmartSonicTSS-I	X	-	X	-
Zpracovávání video obrazu*		Další měřené parametry		
AutoScope	Hustota provozu, otáčení vozidel, kolize			
VideoTrak	Hustota provozu, kolize			
Traficon	Hustota provozu, kolize			
Vantage	Kolize			
Traffic Vision	Tvorba kolon, otáčení vozidel, kolize			

** dopravní systémy využívající zpracování obrazu jsou schopny měřit všechny čtyři tabulkové parametry; podle jejich rozmístění z geografického hlediska pak dokáží na základě centrálního sběru dat z více takových systémů předikovat tvorbu kolon, trasovat vozidla, monitorovat vytížení dopravních komunikací.*

Tabulka 1 – přehled měřených parametrů pro různé detektory

4 MĚŘÍCÍ ŘETĚZEC

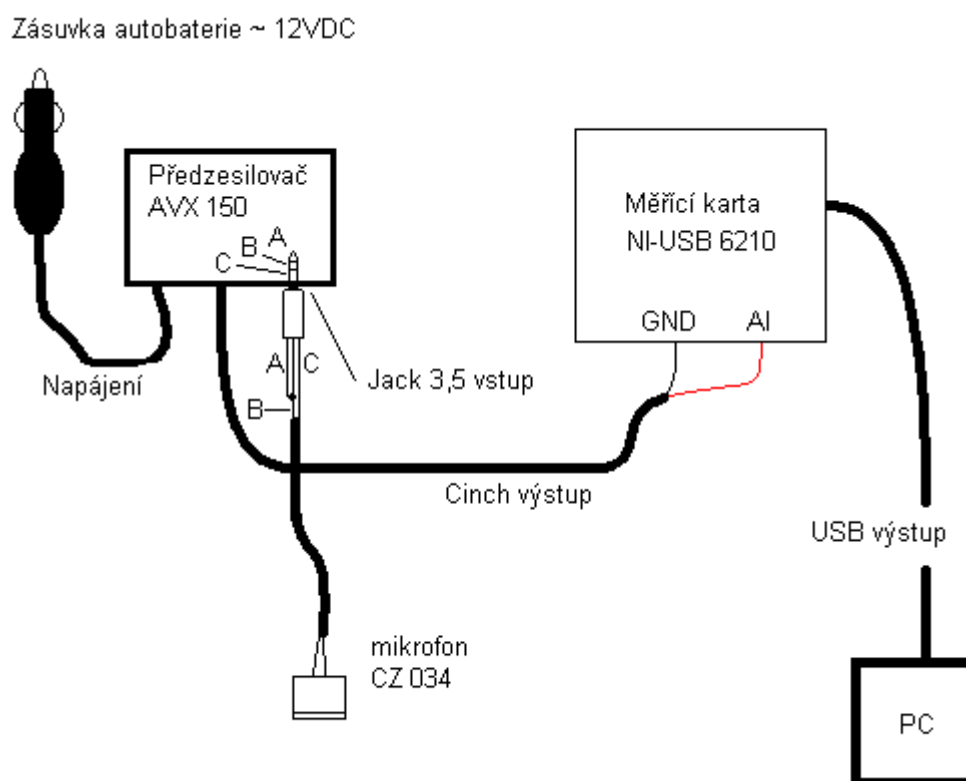
Měřicí řetězec se skládá ze základních bloků:

Mikrofon se zesilovačem

A/D převodník

PC pro vyhodnocení

Pro měření, bez předchozí znalosti měřeného signálu, byl navržen a realizován následující měřicí řetězec. Tímto řetězcem byly zjištěny parametry měřeného signálu, na základě praktického měření v terénu.



Obrázek 2 – schematické znázornění měřicího řetězce č.1

Popis jednotlivých částí měřicího řetězce č.1

Mikrofon – elektretový mikrofon CZ 034

Mikrofonní zesilovač – AVX 150

A/D převodník – měřící USB modul NI-USB 6210

PC – notebook MSI PR201

Elektretový mikrofon CZ034

Parametry:

směrnost: všesměrový

dynamický rozsah (0dB=1V Pa, 1kHz) (dB): -38dB - 52dB

provozní napětí (V DC): 4.5

výstupní odpor (Kohm): 1.0 2.2

impedance: nízká impedance


proudová spotřeba: max. 500uA

snížení citlivosti: méně než -3dB při 1.5V

poměr signál / šum: více než 60dB



Frekvenční charakteristika mikrofonu



Obrázek 3 – frekvenční charakteristika mikrofonu CZ034

Mikrofonní zesilovač AVX150

Parametry:

možnost připojení dynamického i kondenzátorového mikrofonu
vývod napájení kondenzátorového mikrofonu přímo v konektoru
zesílení až +60 dB (1000x)

linkový audio výstup 775 mV/600 ohmů

mikrofonní vstup 0.8 mV/10 k ohmů

provozní napětí (V DC): 12

proudová spotřeba: max. 20mA

kmitočtový rozsah: 40Hz – 25kHz (-3dB)

Nízkošumový mikrofonní mini zesilovač doplněný regulátorem zesílení a výstupem napájení pro kondenzátorový mikrofon.



Měřicí USB modul NI-USB 6210, SN : 142CO28

Parametry:

počet kanálů: 16 SE

vzorkovací frekvence: 250 kS/s

rozlišení: 16 bits

dynamický rozsah: -10..10 V



přesnost rozsahu: 2.69 mV

citlivost rozsahu: 91.6 μ V

paměť na kartě: 4095 vzorků

Notebook MSI PR201

Parametry:

procesor: Intel Core 2 Duo 2,26 GHz

operační paměť: 4 GB

operační systém: Windows 7 Professional 32b

vývojový systém: LabVIEW 2009 professional + advanced signal processing toolkit



4.1 Diskuse parametrů měřícího řetězce č.1


V první fázi bylo provedeno velmi jednoduché měření, které spočívalo pouze v provedení desetiminutového záznamu. Vzorkovací kmitočet byl $f_{vz} = 100kS/s$. Na základě tohoto měření bylo zjištěno, že u osobních vozidel, pohybujících se rychlostí $v \approx 80kmh^{-1}$, jsou nejmarkantnější složky frekvenčního spektra rozloženy okolo frekvence 100Hz. I přesto, že bylo toto měření pouze pro jeden typ vozidla (škoda felicia, pneu 165/70 R 13 zimní), dá se obecně předpokládat, že většina osobních aut bude mít frekvenční spektrum velmi podobné.

Nakonec byla naměřena série 450 průjezdů. Měření bylo provedeno jen pomocí signálu z mikrofону, bez referenčního zdroje pro určení rychlosti nebo detekci vozidla.

Všechna měření byla provedena se stejnou vzorkovací frekvencí. Zesílení předzesilovače se nastavuje analogově bez stupnice. Zesílení bylo nastaveno vždy až na místě měření, není tedy možné stanovit jeho přesnou hodnotu.


Měření byla provedena z auta zaparkovaného vedle silnice (viz obr.3). Pro poslední sérii 450 průjezdů vozidel byla vybrána silnice I. třídy s jedním pruhem pro každý směr. Jednalo se o lokalitu mimo obec s omezením rychlosti na $90kmh^{-1}$, toto omezení platilo pro úsek dlouhý $s \approx 600m$, z obou stran bylo omezení rychlosti na $50kmh^{-1}$, protože silnice spojovala dvě obce. Úsek byl rovný a přehledný, vedl přes pole, na okraji vozovky bylo minimum stromů. Vozovka byla v relativně dobrém stavu a byla suchá. Bylo oblačno, bezvětří. Jednalo se o silnici u Brna, která spojovala Líšeň a Slatinu, na ni navazovaly ulice Drčkova a Bedřichovická Obrázek 4.

Vozidla zde dosahovala rozmanitých rychlostí $v \in (50,120) \text{ kmh}^{-1}$. Změřit přesnější parametry vozovky (šířka, vzdálenost mikrofonu od jednotlivých pruhů, šířka jednotlivých pruhů) nebylo vzhledem k frekventovanému provozu možné.



Obrázek 4 – 1. měřicí lokalita

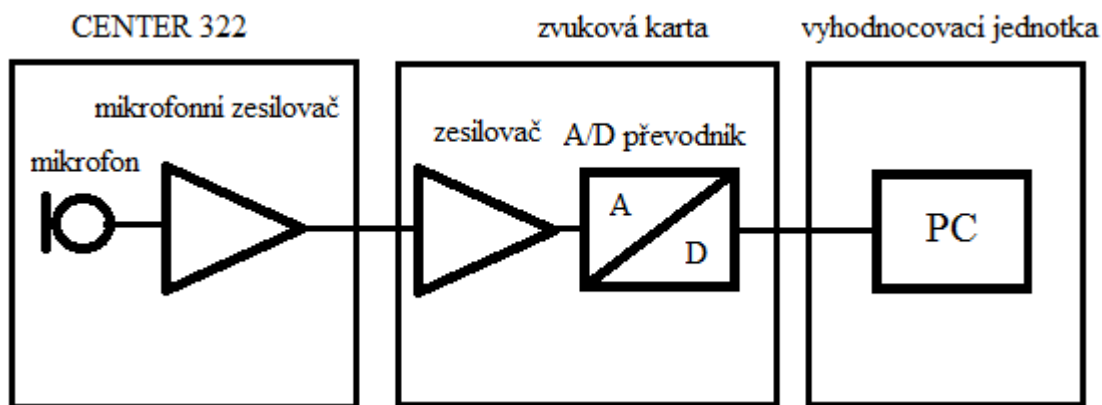
Z naměřených průjezdů, bylo zjištěno typické výkonové spektrum signálu projíždějícího vozidla. Na základě charakteristik výkonového spektra signálu byl měřicí řetězec upraven. Výkonové spektrum vozidla obsahuje spektrální složky odpovídající akustickým zdrojům vozidla ve frekvenčním pásmu $\Delta f \in (50;1000) \text{ Hz}$.



Obrázek 5 – typické výkonové spektrum signálu vozidla

4.2 Návrh ideálního měřicího řetězce

Pro zachování nízkých pořizovacích nákladů systému a s ohledem na dostatečnou funkcionalitu byl pro další měření použit následující měřicí řetězec.



Obrázek 6 – blokové schéma měřicího řetězce č. 2

Popis jednotlivých částí měřicího řetězce č.2

Mikrofon + mikrofonní zesilovač – hlukoměr CENTER 322

A/D převodník – C-Media CMI9880 HD Audio

PC - notebook MSI PR201

Hlukoměr CENTER 322

Parametry:

směrnost: všesměrový

dynamický rozsah: 50 dB; (Low 30-80 dB; Medium 50-100 dB; High 80-130 dB)
frekvenční rozsah: 31,5 Hz – 8 kHz ($\pm 1,5$ dB v referenční úrovni 94 dB na 1 kHz)
zobrazení: tří-místný LCD
typ mikrofonu: elektretový
napájení: 9V baterie
rozměry: 275x64x30 mm
možnost upevnit na fotografický stativ, protivětrný kryt mikrofonu

Zvuková karta

C-Media CMI9880 HD Audio

Použitý frekvenční rozsah: 40Hz – 15kHz (± 1 dB)

Odstup signál šum: -85,6 dB(A)

Dynamický rozsah: 84,2 dB

Harmonické zkreslení: 0,0011 %

Intermodulační zkreslení: 0,049 %

Stereofonní přeslech: -88,8 dB

Notebook MSI PR201

Parametry:

procesor: Intel Core 2 Duo 2,26 GHz

operační paměť: 4 GB

operační systém: Windows 7 Professional 32b

vývojový systém: LabVIEW 2009 professional + advanced signal processing tool



5 POPIS ALGORITMŮ

Návrh a tvorba algoritmu vychází z koncepce detekce projíždějícího vozidla, záznamu jeho akustické stopy a její následné analýzy. Celý zaznamenaný signál je tak zpracováván „offline“.

5.1 Detekce vozidla

Pro detekci projíždějícího vozidla v okolí mikrofonu byly navrženy následující dva algoritmy:

5.1.1 Detekce vozidla na základě efektivní hodnoty snímaného signálu

Detekce vozidla na základě zvýšení efektivní hodnoty výstupního napětí na svorkách mikrofonu. Hodnota je dána jako:

$$\psi_x = \sqrt{\frac{1}{n} \sum_{i=0}^{n-1} |x_i|^2} \quad (1)$$

Pro dosažení dostatečné robustnosti algoritmu, je uvažována difference v čase, tedy rychlost změny této sledované hodnoty. První přístup, ve kterém bylo sledování difference realizováno přímo:

$$\frac{\Delta \psi_x}{\Delta t} > \text{práh} \Rightarrow \text{jedná se o užitečný signál} \quad (2)$$

$$\frac{\Delta \psi_x}{\Delta t} < \text{práh} \Rightarrow \text{konec signálu} \quad (3)$$

nesplňoval požadavky. I přes filtraci průběhu efektivní hodnoty pomocí dolní propusti pro odstranění prudkých změn docházelo k falešným detekcím a záznamu neužitečného signálu vlivem parazitních jevů. Průběh efektivní hodnoty v čase při průjezdu vozidla nemá konstantní trend (blíží se - hodnota narůstá, vzdaluje se - hodnota klesá), hlavně vlivem nedokonalostí ve vozovce a směrovostí akustických zdrojů ve vozidle tak dochází ke „zvlnění“ průběhu, které způsobovalo mylné ukončení záznamu (Obrázek 7). Je tedy nemožné řídit ukončení signálu jen podle poklesu derivace pod určitou mez. Proto je nutné sledovat i aktuální hodnotu ψ_x v kombinaci s její derivací, což vede na:

$$\frac{\Delta \psi_x}{\Delta t} > \text{práh} \ \& \ \psi_x > \text{práh} \Rightarrow \text{jedná se o užitečný signál} \quad (4)$$


$$\frac{\Delta \psi_x}{\Delta t} < \text{práh} \ \& \ \psi_x < \text{práh} \Rightarrow \text{konec signálu} \quad (5)$$

Aby nebylo potřeba v reálném čase průběh filtrovat a počítat jeho diferenci je tento proces realizován porovnáváním dvou nestejně dlouhých plovoucích průměrů této hodnoty, s využitím různé hystereze pro začátek i konec záznamu.

$$\sqrt{\frac{1}{n_1} \sum_{i=0}^{n_1-1} |x_i|^2} > h_1 \sqrt{\frac{1}{n_2} \sum_{i=0}^{n_2-1} |x_i|^2} + offset \Rightarrow \text{jedná se o užitečný signál} \quad (6)$$

$$\sqrt{\frac{1}{n_1} \sum_{i=0}^{n_1-1} |x_i|^2} < h_2 \sqrt{\frac{1}{n_2} \sum_{i=0}^{n_2-1} |x_i|^2} + offset \Rightarrow \text{konec signálu} \quad (7)$$

Kde n_1 je počet vzorků aktuálního a n_2 dlouhodobého signálu, h_1 a h_2 je hodnota příslušné hystereze v intervalu $h \in (1;10)$. Hodnotou hystereze a délkou porovnávaných polí je pak možné měnit velikost difference pro kterou se začne a přestane signál nahrávat.



Obrázek 7 – Průběh efektivní hodnoty signálu a její derivace

5.1.2 Detekce vozidla na základě signálového spektra

Tento způsob detekce využívá odlišnosti frekvenčního spektra signálu projíždějícího vozidla od frekvenčního spektra neužitečného signálu. Je tak sledována odchylka projekce spektra aktuálního signálu do podprostoru tvořeného vlastními vektory kovarianční matice trénovacích dat.

Detekce na základě této metody je odvozena z algoritmu pro signálovou klasifikaci, využívající metody analýzy nejdůležitějších komponent signálu, známým jako PCA (principal component analysis).

Popis trénování množiny

Z předchozích signálů jsou vybrány ty, které jsou nejméně zatíženy šumem prostředí. Trénování množina je pak dána jako kovarianční matice:

$$M_{\text{cov}} = \frac{1}{N} \sum_{n=1}^N (\overline{\Phi}_n - \overline{\Gamma})(\overline{\Phi}_n - \overline{\Gamma})^T \quad (8)$$

Kde $\overline{\Gamma}$ je průměrný vektor trénovacích dat definovaný jako:

$$\overline{\Gamma} = \frac{1}{N} \sum_{n=1}^N \overline{\Phi}_n \quad (9)$$

$\overline{\Phi}_n$ je normalizovaný vektor v logaritmickém měřítku spektra signálu vozidla $\overline{\phi}_n$:

Počet spektrálních čar ϕ_{ni} pro každý n-tý vektor reprezentující vozidlo je $N = 1000$.

$$[\phi_{n0}, \phi_{n1}, \dots, \phi_{n999}]^T = \frac{\overline{\phi}_n}{\sum_{i=0}^{999} \phi_{ni}} \text{ a } \phi_{ni} = C_2 \log_{10}(C_1 \phi'_{ni} + 1) \quad (10)$$


pro $n = 1, 2, \dots, N$ vektorů.

Pak $\overline{\Phi}_n = [\phi_{n0}, \phi_{n1}, \dots, \phi_{n999}]^T$

Konstanty C_1 a C_2 byly stanoveny na 100 000 resp. 100 podle [CITACE].

Platí [CITACE], že variantnost dat kovarianční matice je možné seřadit podle velikosti vlastních čísel matice a jim odpovídajících vlastních vektorů. Na tomto principu je metoda PCA založená. Platí pak, že:

$\Psi(\overline{\phi}_{\text{cov},k}) = \lambda_k$, kde Ψ je funkce popisující varianci skalárů vektoru a λ_k je vlastní číslo odpovídající vektoru $\overline{\Theta}_k$ kovarianční matice. Díky tomu, když seřadíme vlastní vektory podle velikosti jim odpovídajících vlastních čísel, můžeme odříznout vektory, které nejméně popisují varianci dat kovarianční matice. Počet M vektorů, které nejlépe danou matici vystihují byl zvolen $M = 35$ podle (Obrázek 8)



Obrázek 8 – Rozložení vlastních čísel kovarianční matice

Promítnutí nového vektoru $\bar{\gamma}$ upraveného podle rovnic $[\phi_{n0}, \phi_{n1}, \dots, \phi_{n999}]^T = \frac{\bar{\phi}_n}{\sum_{i=0}^{999} \phi_{ni}}$

a $\phi_{ni} = C_2 \log_{10}(C_1 \phi'_{ni} + 1)$ (10) do podprostoru tvořeného

vlastními vektory $\bar{\Theta}_k$ kovarianční matice se provádí výpočtem hlavních komponent nového

vzoru: $w_k = (\bar{\gamma} - \bar{\Gamma})^T \cdot \bar{\Theta}_k$ pro $k = 1, 2, \dots, M = 20$ (11)


Reziduální vektor (vzdálenost od trénovací množiny) se pak vypočítá jako :

$$\bar{\varepsilon} = \bar{\gamma} - \bar{\Gamma} - \sum_{k=1}^M w_k \bar{\Theta}_k \quad (12)$$


Jeho velikost (délka), která je definována jako : $\|\varepsilon\| = \sqrt{\varepsilon_0^2 + \varepsilon_1^2 + \varepsilon_2^2 + \dots + \varepsilon_i^2}$, přímo určuje vzdálenost nového vzoru od trénovací množiny.

5.1.3 Diskuse obou algoritmů

Algoritmus založený na sledování efektivní hodnoty napětí je jednoduchý, výpočetně nenáročný a snadno nastavitelný. Jeho hlavní nevýhodou je falešná detekce vozidel, způsobená zvuky prostředí a větrnými rázy do snímací části mikrofону. Další nevýhodou je také neschopnost od sebe oddělit větší počet za sebou jedoucích vozidel (Obrázek 9). Při jejich průjezdu nedojde k dostatečnému poklesu sledované hodnoty a proto pokračuje záznam signálu.



Obrázek 9 – Detekce dvou po sobě jedoucích vozidel




Obrázek 10 – Průběh efektivní hodnoty pro signál z Obrázek 9

Metoda pro detekci vozidla založená na sledování spektra signálu v čase je výpočetně náročnější, na použité hardwarové konfiguraci (kapitola 4) spotřebovala pouze detekční smyčka programu průměrně 5% procesorového času pro délku časového okna 1s při podvzorkování signálu na 2000 vz./s. Schopnost detekce této metody velmi závisí na následujících faktech:


- Podobnost signálů trénovací množiny s reálnými detekovanými signály. Signály pro trénování množinu musí být ze stejného nebo podobného místa, v jakém je zamýšleno měřit.
- Zvolený kompromis mezi časovým a frekvenčním rozlišením srovnávaného spektra. Je tudíž důležité aby trénování i reálná data měla stejný počet vzorků jak v časové tak frekvenční oblasti (stejně rozlišení a stejná velikost spektra).

- Neměnné akustické pozadí v měřicím místě (déšť, vítr, ostatní hluk). Změna akustického pozadí se projeví změnou spektra měřeného signálu.




Obrázek 11 - závislost velikosti reziduálního vektoru ε na efektivní hodnotě výstupního napětí mikrofону

Funkčnost metody velmi dobře popisuje Obrázek 11. Jedná se o funkční závislost velikosti reziduálního vektoru ε na efektivní hodnotě výstupního napětí mikrofonu při průjezdu jediného vozidla. Druhá veličina dobře koresponduje se vzdáleností vozidla od mikrofonu. Velikost ε je tak možným indikátorem přítomnosti vozidla u mikrofonu. Velikost $\varepsilon = \varepsilon / 5000$.



Obrázek 12 – spektrogram průjezdu nákladního vozidla



Obrázek 13 - průběh velikosti ε k Obrázek 12

V případě detekce většího počtu vozidel jedoucích za sebou, případně proti sobě tato metoda selhává. Díky více vozidlům existuje více akustických zdrojů, což způsobí

změnu frekvenčního spektra signálu. I přesto, že u křížících se vozidel, nebo vozidel jedoucích v těsné blízkosti je velmi obtížné určit jejich rychlost, jejich detekce je stále žádoucí. Stejně jako metoda založená na sledování efektivní hodnoty, i tato je nespolehlivá díky zvukům v pozadí. Zvuky, jejichž průvodce není automobil sice nezpůsobí falešnou detekci, ale ovlivní detekci právě projíždějícího vozidla. Situaci dobře popisuje Obrázek 12. Jedná se o závislost frekvenčního spektra na aktuálním čase. Nákladní vozidlo projíždí kolem mikrofону a způsobí silnou turbulenci, která se významně projeví ve spektru signálu. Tomuto spektrogramu pak odpovídá průběh velikosti $\varepsilon = \varepsilon / 5000$ (Obrázek 13).

Zde uvedené průběhy velikosti vektoru ε jsou počítány z frekvenčních spekter částí signálu o $n=1000$ vzorků, s posunem 100 vzorků pro lepší demonstraci změny této hodnoty. Na části signálu je aplikováno Hanningovo okno.

Oba algoritmy splňují funkci pro kterou byly vytvořeny. Algoritmus založený na sledování efektivní hodnoty napětí se pro detekci vozidel osvědčil lépe, je jednodušší, snadno nastavitelný a výpočetně nenáročný. Algoritmus založený na sledování spektra signálu by se po optimalizaci vytváření báze pro srovnávání průjezdů dal uvažovat jako doplňkový, jeho výstup se dá dále použít pro klasifikaci vozidel při použití více trénovacích množin. Tato skutečnost nebyla v této práci ověřena.

Popis konečné verze algoritmu pro detekci

Použit je první diskutovaný algoritmus rozšířený následujícím způsobem.

- Pro omezení vlivu parazitních jevů na detekci je na základě znalosti signálového spektra vozidla předřazena pásmová propust pomocí IIR filtru s následujícími parametry:

Topologie filtru : Butterworth,

řád = 5,

nižší frekvence propusti $f_{low} = 100Hz$,

vyšší frekvence propusti $f_{high} = 100Hz$,

záchvěv v propustném pásmu $PB_{ripple} = 1dB$,


útlum zádržného pásma $SB_{atten} = 60dB$.

Parametry byly částečně odhadnuty ze znalosti spektra signálu většiny vozidel a na základě měření v terénu metodou pokus-omyl upraveny.

Filtr je použit pouze pro výpočet efektivní hodnoty v daném pásmu, zaznamenává se korespondující originální signál.

- Ze znalosti přibližné rychlosti vozidel pohybujících se po komunikaci jsou vzorky kratší než T_{\min} zahozeny. Volba parametru T_{\min} závisí na měřícím místě (v zástavbě, na poli, les) a odhadované rychlosti vozidel v daném místě. Je vždy nutno volit kompromis mezi mírou falešné detekce a mírou „zahozených“ průjezdů.
- Detekce více průjezdů v jednom záznamu. Na průběh efektivní hodnoty je aplikována dolní propust pro vyhlazení jejího průběhu. V tom jsou následně hledány „údolí“ na šířce signálu odpovídající typicky jedné sekundě záznamu. Signál je následně rozdělen na jednotlivé bloky podle místa „údolí“. Funkčnost algoritmu závisí na nastavení vyhlazovacího filtru a na správném nastavení šířky okna vzhledem k vzorkovací rychlosti vstupního signálu.

Algoritmus prokládá oknem vymezenou část signálu kvadratickým polynomem. Následující „údolí“ je detekováno pro průchodu alespoň polovinou bodů šířky zvoleného okna.



Obrázek 14 – průběh efektivní hodnoty napětí mikrofonu, okno pro hledání „údolí“ a nalezené místo pro rozdělení signálu.

Na konci detekce jsou opět zahozeny signály kratší než T_{\min} .

5.2 Analýza frekvenčního spektra signálu

Přechod z časové oblasti do frekvenční umožňuje několik různě implementovaných metod. V této kapitole se pokusím shrnout možnosti jejich uplatnění pro sledování významných frekvencí v zaznamenaném signálu vozidla.

Obecně se tyto metody dají rozdělit do dvou skupin – neparametrické a parametrické.

Periodogram – odvozeny od DFT, nemají konzistentní odhad, pro zlepšení statistických vlastností se používá nasobení signálu oknem. Omezené možnosti pro krátké signály; nízké rozlišení. Špatný odhad pro úzkopásmové procesy navzájem velmi blízké ve frekvenční oblasti. Výhodou je, že není nutné mít jakoukoliv znalost o chování signálu. **Metoda minimální variance**, známá taky jako Caponova metoda – data-adaptivní modifikace periodogramu. Využívá banky filtrů typu pásmová propust. Výsledná hodnota výkonu pro určité frekvenční pásmo je pak určena jako podíl výstupního výkonu filtru a šířky jeho pásma. Náročnější na výpočetní čas. Poskytuje mnohem lepší frekvenční rozlišení než metody odvozené od DFT.

Parametrické metody – tyto metody využívají faktu, že pokud je možné nalézt model systému, který na vstup bílého šumu odpoví výstupem analyzované sady dat, můžeme pak PSD takové sady dat určit jako frekvenční odezvu právě takového systému. Tyto metody zastřešují různé způsoby modelování takového systému a různé metody pro určení koeficientů systému. Limitujícím faktorem těchto metod je určení modelu, který by analyzovaný signál generoval.

5.2.1 Periodogram

Metoda odhadu výkonové spektrální hustoty (dále jen PSD) signálu pomocí periodogramu je nejpoužívanější neparametrickou metodou. Tato metoda počítá PSD pomocí rychlé Fourierovy transformace na základě následující rovnice:

$$PSD(f) = \frac{|FFT(W_t \times X_t, f)|^2}{L} \times \frac{1}{\Delta f} \quad (2)$$

Hlavním limitujícím faktorem této metody je odhad PSD využitím diskrétní Fourierovy transformace. Ta je definována podle následující rovnice:


$$y_k = \sum_{n=0}^{N-1} x_n e^{-j2\pi kn/N} \quad \text{pro } n = 0, 1, 2, \dots, N-1 \quad (3)$$

Pozn.: doplněním vstupního vektoru X nulami dojde pouze k interpolaci spektra, není tak možné získat lepší frekvenční rozlišení.

Je tak možné získat $k = N$ spektrálních čar dvoustranného spektra. Frekvenční rozlišení je pak dáno:


$$\Delta f = \frac{N}{f_{vz}}, \quad (4)$$

z čehož plyne neurčitost mezi časovou a frekvenční oblastí a je nutné zvolit kompromis. V případě vozidla je k dispozici vždy časově omezený signál a při průjezdu kolem mikrofonu, umístěném v určité vzdálenosti od vozovky, se vlivem Dopplerova jevu významně mění za pevně daný časový okamžik. Při pokusu o sledování změny frekvence pomocí dostatečně dlouhého okna s malým přesahem (dostatečné časové i frekvenční rozlišení) už nebude výsledné PSD reprezentovat dostatečně aktuální signál a významné frekvence se začnou „slévat“ dohromady. Jejich sledování pak není možné. Tuto neurčitost popisuje Obrázek 15. Tento problém limituje všechny metody, využívající pro odhad PSD diskrétní Fourierovu transformaci.



Obrázek 15 – závislost frekvenčního rozlišení na časové délce zkoumaných dat

Tato metoda je pro sledování významných frekvencí nepoužitelná.



Obrázek 16 – blokové schéma odhadu PSD pomocí MNV

5.2.2 Metoda minimální variance

Výkonové spektrum je odhadováno pomocí filtrace signálu bankou filtrů typu pásmová propust. Tato metoda je velmi podobná periodogramu. Pokud popíšeme periodogram jako banku filtrů

$$H(z) = \frac{\sin[N(\omega - \omega_i)/2]}{N \sin[(\omega - \omega_i)/2]} \quad (5)$$

Uvažujeme $y(n) = H(n)x(n)$ pak výstupní výkon takových filtrů pro stejnou vstupní

$$\text{posloupnost udává výkon na dané frekvenci } \omega. \quad \hat{E}\{y_i(n)^2\} = |y_i(N-1)|^2 \quad (6)$$

PSD pro jednotlivá frekvenční pásma pak odpovídá ploše v daném pásmu, ta je dána

$$\text{jako: } \hat{P}_x(e^{j\omega_i}) = \frac{E\{y_i(n)^2\}}{1/N} \text{ kde } 1/N \text{ je šířka pásma filtru} \quad (7)$$

Pro periodogram platí, že všechny filtry jsou stejné a každý je „stranou“ centrální frekvence. Výsledkem je, že pokud zkoumaný proces obsahuje významné množství energie ve frekvenčním pásmu postraních laloků filtru, dojde také k významnému zkreslení jeho spektra.

Řešením je použít takovou banku filtrů, ve které se šířka každého filtru přizpůsobila tak, aby co nejvíc potlačila frekvenční komponenty mimo zkoumané pásmo (Obrázek 16 – blokové schéma odhadu PSD pomocí MNV).

Metoda minimální variance využívá banku filtrů navržených tak, aby zesílení filtru pro frekvenci $\omega = \omega_i$ bylo 1. Takže platí: $G_i(\omega) = \sum_{n=0}^p q_i(n) e^{-jn\omega_i} = 1$ (8)

$$\text{Pro nalezení řešení je třeba najít minimum funkce } E\{y_i(n)^2\} = G_i^H R_{xx} G_i \quad (9)$$

$$\text{Řešení je ve tvaru } \hat{P}_{\text{Capon}}(e^{j\omega}) = \frac{p+1}{e^H R_x^{-1} e} \quad (10)$$

kde e je vektor komplexních exponenciál $e_i = [1, e^{j\omega_i}, \dots, e^{jp\omega_i}]^T$ a p je počet z-členů FIR filtru. Ideální by tedy bylo pokud by se řád filtru blížil k nekonečnu. Řád filtru ovlivňuje velikost $(p+1) \times (p+1)$ autokorelační matice R_x . Nalezení její inverze je nejvíce limitujícím faktorem této metody.

5.2.3 Parametrické metody

Parametrické metody předpokládají, že systém $H(z)$ buzený bílým šumem generuje analyzovanou sadu dat právě, když je jeho modulová charakteristika stejná jako PSD signálu. Pokud je tedy možné daný model sestavit co nejpřesněji, je možné na základě jeho frekvenční odezvy vypočítat PSD signálu.



Obrázek 17 – systém buzený bílým šumem generuje analyzovaný signál

$$\text{PSD pak bude dáno jako } P(e^{j\omega_i}) = H(e^{j\omega_i}) \quad (11)$$


$$\text{Kde } H(z) = \frac{Y(z)}{X(z)} = \frac{b_m z^{-m} + \dots + b_0}{a_n z^{-n} + \dots + a_0} \quad (12)$$

Pro m a n stupně polynomu.

Tyto modely se dělí na:


- AR – autoregressive model, často také all-poles model. Tento model obsahuje pouze póly a žádné nuly. Čitatel je tak reprezentován pouze b_0 .
- MA – moving average model, all-zeros model. Model obsahuje pouze nuly, jmenovatel je reprezentován pouze koeficientem a_0 .
- ARMA – kombinací AR a MA modelů, obsahuje nuly i póly.

PSD odhadnuté za použití těchto metod má svoje charakteristiky a významně se liší pro stejný signál. MA model má slabou schopnost odhadu frekvenčních špiček. A není pro jejich sledování vhodný. Vlastnosti modelů AR a ARMA dobře popisují obr a obr.



Obrázek 18 – PSD, řád polynomu $\text{or(AR)}=1/40$, $\text{or(ARMA)}=7/43$

Signál generovaný třemi sinusovkami s blízkými frekvencemi je zatížen šumem. Pro stejný signál jsou uvedeny dvě PSD pro demonstraci hlavní nevýhody parametrických metod. První PSD odpovídá odhadu s dobře zvoleným stupněm polynomu. Všechny tři frekvenční špičky jsou pro obě metody dobře čitelné a nebyl by problém programově získat jejich hodnoty. Druhý odhad PSD je pro stejný signál se špatně zvoleným řádem polynomu. Frekvenční špičky už není možné detekovat.



Obrázek 19 – PSD, řád polynomu $or(AR)=1/25$, $or(ARMA)=7/26$

Další skupinou moderních parametrických metod, jsou metody, které předpokládají harmonický model signálu. Takovou metodou je metoda MUSIC (multiple signal classification). Tento algoritmus počítá hodnoty výkonu jednotlivých frekvenčních složek, které jim neodpovídají a nejsou vůči nim proporcionální. Takové PSD je nazýváno pseudo PSD.

Za předpokladu, že vstupní vektor dat může být reprezentován řadou komplexních sinusovek s přidaným šumem, tento algoritmus nejdříve vypočítá autokorelační matici R_x , určí její vlastní vektory V a k nim příslušné vlastní hodnoty λ . Vlastní vektory s velkými vlastními čísly tvoří signálový podprostor a zbylé vlastní vektory tvoří podprostor šumu. Signálový podprostor se dá také pospat jako $e(\omega_i) = [1, e^{j\omega_i}, \dots, e^{Mj\omega_i}]$ pro M prvních vlastních vektorů. Pokud vstupní vektor dat obsahuje složku ω , je vektor příslušný k $e^{j\omega_i}$ dekorelován s podprostorem šumu. Následující výraz pak dosáhne maxima právě pro ω_i .


$$PSD_{pseudo}(\omega_i) = \frac{1}{\sum_{k=M+1}^p |e^T(\omega_i) V_k|^2} \times \frac{1}{\Delta f} \quad (13)$$

Modifikovaná metoda MUSIC pak používá jednotlivá vlastní čísla λ , příslušná k aktuálnímu vlastnímu vektoru V , jako váhovací prvek. Skalární hodnota jmenovatele

$$\text{je pak dána jako } JMEN = \sum_{k=M+1}^p \left| \frac{1}{\lambda_k} e^T(\omega_i) \mathcal{V}_k \right|^2 \quad (14)$$

5.3 Možnosti sledování frekvence v čase

Spektrum signálu se s průjezdem vozidla mění. Jeho tvar není v čase stejný a jen velmi málo podobný. Během průjezdu vozidla jsou postupně slyšet různé akustické zdroje s různou intenzitou a často blízkých frekvencí. Není tak možné korelovat navzájem jednotlivá spektra v čase. Obrázek 20 demonstruje změnu tvaru spektra v čase průjezdu vozidla pro šířku okna 200 vzorků.



Obrázek 20 – STFT spektrogram průjezdu vozidla

Další možností je sledování významné spektrální složky, který by byla snadno odlišitelný od ostatních. Spektrální složka nese informaci o frekvenci a amplitudě, pokud frekvence není známá a je třeba ji dohledat, jediný způsob je tak na základě amplitudy. Pokud tedy existuje ve vozidle dostatečně silný akustický zdroj, který by byl slyšitelný po celou dobu průjezdu vozidla je pravděpodobné, že bude reprezentovaný určitým počtem spektrálních složek natolik silných, že nebude problém je programově odlišit od šumu a blízkých méně výkonných frekvencí.

Sledování takových významných složek pak závisí na schopnosti metody, která transformuje signál z časové oblasti do frekvenční správně určit její výkon ve smyslu proporcionality k ostatním frekvenčním složkám. Pokud se stane, že amplituda sledované frekvence klesne na takovou hodnotu, že již není možné ji odlišit od

ostatních, snadno dojde k situaci, že znovu objevená frekvence nebude původní. Pokud takto algoritmus „přeskočí“, není již možné rychlost vozidla správně odhadnout.


Při návrhu algoritmu, který označí ideálního kandidáta pro sledování, je zohledněna povaha Dopplerova jevu. Pokud je uvažováno celé frekvenční spektrum kompletního průjezdu, bude výkon, byť jen jediné frekvenční složky, rozložen do frekvenčního pásma o šířce přímo úměrné rychlosti vozidla a frekvenci takové složky. Podle

$$\text{rovnice } f = \left(\frac{c + v_r}{c + v_s} \right) f_0,$$


$$(1 \text{ je šířka tohoto pásma rovna } \Delta f = 2 \left(\frac{c + v_r}{c + v_s} \right) f_0$$

(15)

Funkci algoritmu dobře demonstrují následující obrázky



obrázek 21 – hodnocené spektrum



obrázek 22 – ohodnocení spektra

PSD signálu je vypočteno pomocí periodogramu, protože pro delší signály je jeho funkčnost postačující. Pod obrázkem spektra signálu je jeho ohodnocení, na základě poměrového kritéria. Maximální hodnota je dobře viditelná a její korespondující frekvence je pak ve spektru signálu vyznačena červeným kolečkem. Pokud je tedy k dispozici frekvenční pásmo se středovou frekvencí nalezenou podle výše zmíněného algoritmu, je nutné tuto frekvenci sledovat v čase.


5.4 Optimální metoda pro sledování významné frekvence

V této části textu je diskutována vhodnost metod (5.2) pro přechod z časové oblasti do frekvenční oblasti.

Optimální metoda je zvolena na základě dvou kritérií :


přesnost odhadu spektra, hlavně frekvenčních špiček pro různé vstupní vektory
výpočetní náročnost metody

I přesto, že není k dispozici přesné spektrum signálu, existuje způsob jak ověřit do jaké míry si metoda odhad spektra „vymýšlí“. To je možné poznat z jeho změny za velmi krátký časový okamžik.




Obrázek 23 – spektrum dvou částí signálu navzájem posunutých o 25ms

Tuto změnu pro dvě různé metody ukazuje Obrázek 23 a Obrázek 24. Jedná se o totožnou část signálu. Zatímco odhad spektra pomocí metody MMV se téměř nezměnil, pomocí metody AR došla k radikální změně. Frekvenční špičky, jejichž amplituda byla původně (černé spektrum) dostatečně významná o 25ms později (červené spektrum) zcela „zmizí“ (např. frekvence 400 a 800 Hz). Různé metody výpočtu koeficientů parametrických modelů vedou k velmi odlišným spektrálním odhadům (Obrázek 25).



Obrázek 24 - spektrum dvou částí signálu navzájem posunutých o 25ms



Obrázek 25 – Porovnání různých algoritmů pro nalezení koeficientů modelu AR

Nastavení optimálních parametrů použitých parametrických metod


Následující parametry a algoritmy pro stanovení koeficientů modelů byly odhadnuty na základě částečných znalostí signálu a následně upraveny metodou pokus-omyl.

AR - Při nastavení stupně polynomu zohlednit model systému, který danou časovou řadu generuje. To v tomto případě nelze. Při experimentálním nastavování různých algoritmů pro výpočet koeficientů pro různé stupně modelu bylo zjištěno, že stupně polynomu, nastavené odhadnuté algoritmem „Yule-walker“, do 150 nemají tendenci vést ke vzniku nahodilých špiček vzniklých šumem. Čím byl stupeň polynomu vyšší, tím „ostřejší“ pak bylo výsledné spektrum.

ARMA – tento model dává stejně přesný a rozlišitelný odhad špiček jako model typu AR. Parametrizace polynomu tohoto modelu je velmi podobná jako u modelu typu AR. Protože stanovení koeficientů pro tuto metodu stejným algoritmem, Yule-Walker, je ale výpočetně náročnější, není už dál uvažována.

MMV – tato metoda nevyžaduje stanovení parametrů, je potřeba zvolit stupeň použitého filtru. Zde je nutné volit mezi rozlišením ve frekvenční oblasti a výpočetní náročností metody, řád filtru byl volen 100 až 150.

MUSIC – ačkoliv je tato metoda založena modelování procesu podobně jako AR a ARMA, v porovnání s nimi je velmi robustní. Spektrální odhady pomocí této metody jsou „podobné“ odhadům získaným metodou MMV (amplituda spektrálních složek získaných pomocí MUSIC algoritmu neodpovídá reálné hodnotě výkonu v dané frekvenci, jedná se o pseudospektrum).



Obrázek 26 – PSD metodami MUSIC a MMV (Capon) normalizované na společné měřítko

Výpočetní náročnost metod

Na uvedené HW konfiguraci byla porovnána výpočetní náročnost metod

Metoda	Čas pro výpočet PSD [ms]	20 iterací [s]	50 iterací [s]
MMV	220; 140*	4,5; 2,5*	11; 7*
AR	25	0,5	1,3
MUSIC	180	3,5	9

Tabulka 2 - porovnání výpočetní náročnosti metod

**první číslo udává čas pro výpočet celého spektra, druhé číslo je doba potřebná na výpočet pouze frekvenčních špiček a jejich amplitud*

Tabulka 2 ukazuje srovnání metod použitých pro spektrální analýzu stejné části signálu o délce $N=350$ vzorků, s požadovaným frekvenčním rozlišením $1/4\text{Hz}$. Pokud uvažujeme průměrnou délku zaznamenaného signálu 2s – 5s, pak při šířce časového okna 350 vzorků, vzorkovací rychlosti 2000 Hz a přesahu okna 50% je třeba provést 20–60 takových odhadů.

Použité metody měly následující nastavení:

AR; řád polynomu 1/150; algoritmus „Yule-Walker“

MUSIC; rozdělení podprostoru signál/šum 80/20; na signál je aplikováno Hanningovo okno s délkou $N=350$

MMV; řád filtru 149

Ačkoliv, vypadá průměrný výpočetní čas kriticky, díky modulárnímu návrhu celého program je možné zaznamenané průjezdy „bufferovat“ a rychlost u nich určit až bude komunikace bez provozu. Díky zamýšlenému konceptu navrhovaného zařízení, tedy primárně pro statistický sběr dat, nevadí, pokud budou data tímto způsobem zpracovávána zpětně s driftem v řádu minut.

Na základě provedených měření, a subjektivním posouzení vhodnosti metody se jako nejvhodnější jeví metoda MMV a metoda MUSIC.

5.5 Výpočet rychlosti

Rychlost vozidla je možné odhadnout z průběhu sledované frekvenční složky. Jeden z možných přístupů, za předpokladu, že je pozorovatel dostatečně blízko dráhy zdroje, je určit frekvenci, se kterou se zdroj přibližuje f_1 , resp. vzdaluje f_2 . Získáme tak dvě různé frekvence a za předpokladu konstantní frekvence z pohledu zdroje platí:

$$v_s = \frac{c}{\left(\frac{f_0 + \Delta f}{f_0} \right)} - c \quad (16)$$

$$\text{kde } f_0 = \frac{1}{2}(f_1 + f_2) \quad (17)\text{a}$$

$$\Delta f = \frac{1}{2}(f_2 - f_1) \quad (18)$$

Tento způsob je jednoduchý, nerobustní a není žádná možnost ověření správnosti takového výpočtu (kromě případů je-li výstupem nesmyslná rychlost).

Lepším způsobem je zohlednit celý průběh sledované frekvenční složky, případně všechny frekvenční špičky a jejich amplitudy ve zvoleném pásmu. Následně navržením inteligentního filtru získat nejpravděpodobnější průběh a zkoumat, jaký model by takový průběh pro jednu spektrální složku generoval. Pokud je možné takový model získat, jeho parametry už přímo nesou informaci o rychlosti vozidla. Toho je dosaženo pomocí algoritmu uvedeného na Obrázek 27 – algoritmus pro sledování významné spektrální složky Obrázek 27.

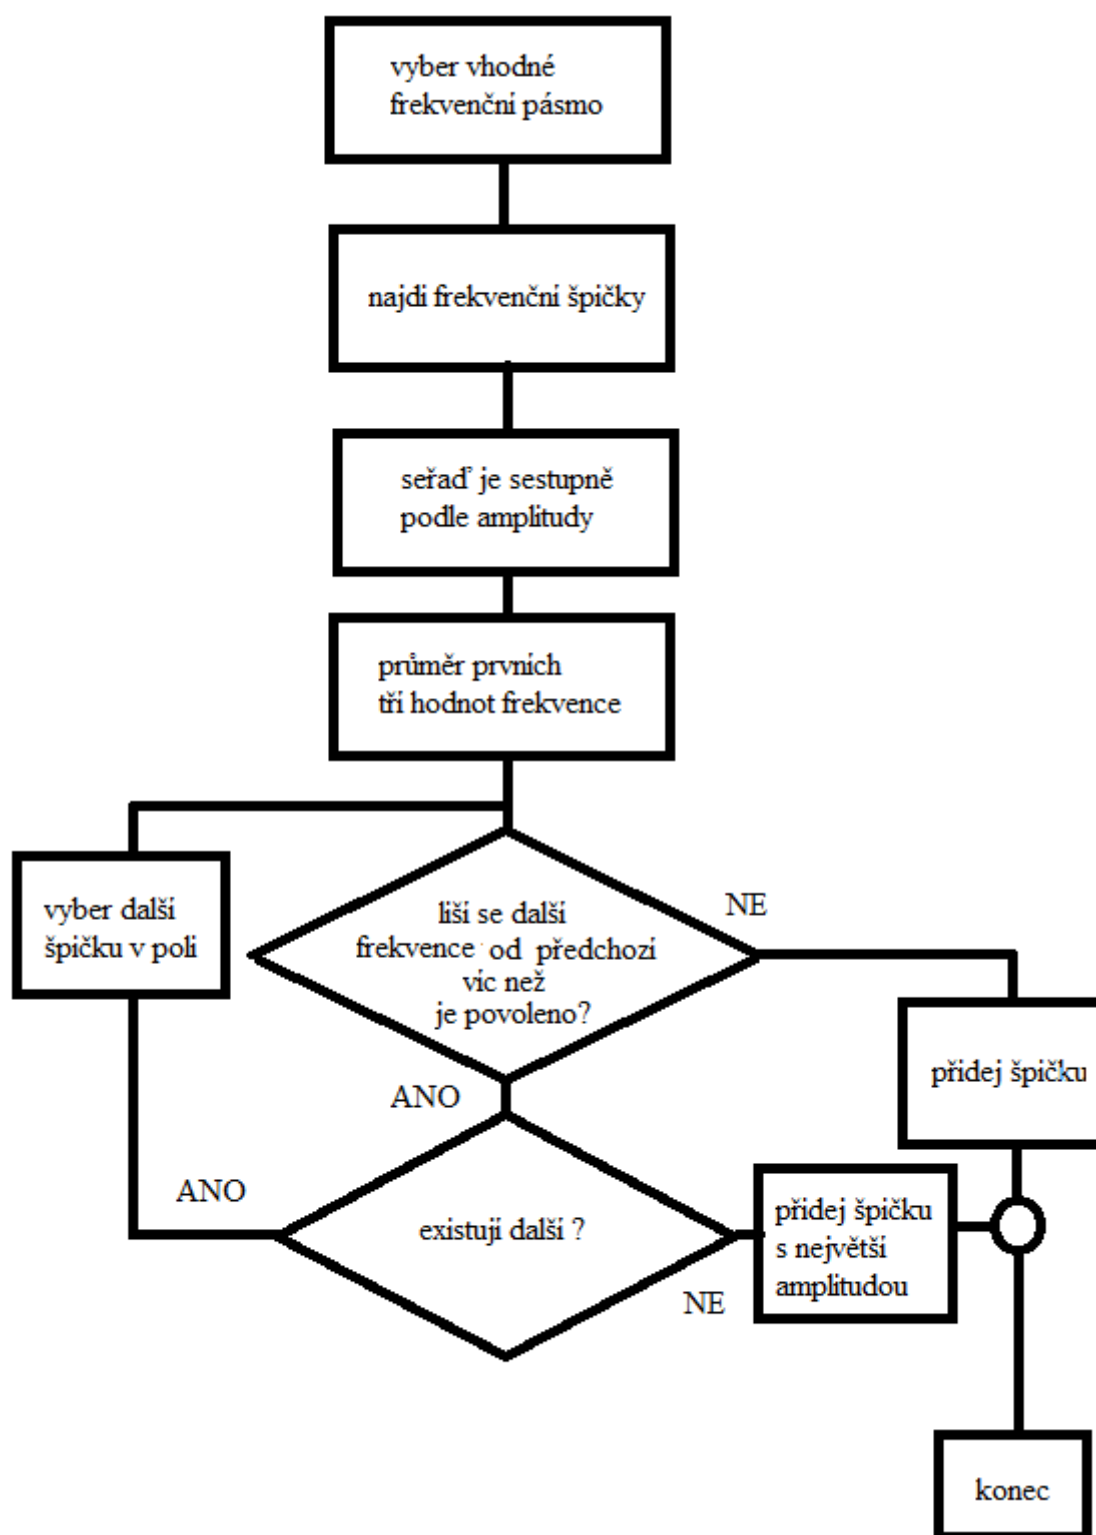
V případě, že je již k dispozici frekvenční průběh, zbývá správně zvolit parametry modelu, který by takový průběh generoval. Model změny frekvence při průjezdu auta je možné odvodit z rovnice pro Dopplerův jev pro pozorovatele s nulovou rychlostí stojícího bokem trajektorie vozidla.

$$f = poz \times \cos \left[\operatorname{tg} \left(\frac{S_{\text{mikrofonu}}}{S_{\text{vozidla}}} \right) \right] \left[f_0 - \left(\frac{v_{\text{vozidla}}}{c} - 1 \right) f_0 \right] + f_0 \quad (19)$$


$$\text{kde veličina } poz = \begin{cases} 1 & \text{pro blížící se vozidlo} \\ -1 & \text{pro vzdalující se vozidlo} \end{cases}$$

Pro správné zvolení parametrů je použita metoda „Levenberg-Marquardt“. Tato metoda minimalizuje váhovaný čtverec odchylky mezi známou posloupností a posloupností generovanou modelem.

Jako váha jednotlivých bodů je zvoleno trojúhelníkové okno, které nabývá hodnoty 1 právě když vozidlo projíždí kolem mikrofону (odvozeno z průběhu efektivní hodnoty) a hodnoty 0 na začátku, respektive na konci. Tímto oknem se potlačí možné nepřesnosti v odhadu frekvence v místech, kde akustický zdroj už nemusí být snadno identifikovatelný.



Obrázek 27 – algoritmus pro sledování významné spektrální složky



Obrázek 28 – váhovací okno pro vstupní posloupnost, kterou je třeba modelovat

Je zřejmé, že nebude možné funkci modelu (rovnice

$$f = poz \times \cos \left[tg \left(\frac{S_{mikrofonu}}{S_{vozidla}} \right) \right] \left[f_0 - \left(\frac{v_{vozidla}}{c} - 1 \right) f_0 \right] + f_0 \quad (19)$$

parametrizovat tak, aby přesně odpovídala vstupní posloupnosti dat. Je tedy třeba podmínit ukončení iterace při hledání takového modelu. Výsledná odchylka výstupu modelu vůči vstupní posloupnosti a odhadované parametry modelu jsou dobrými indikátory pro stanovení, zda frekvenční průběh na který se snaží model parametrizovat odpovídá frekvenčnímu průběhu, ze kterého je možné rychlost určit. Tato skutečnost je dále rozvedena v kapitole Demonstrace algoritmu.

5.6 Implementace algoritmů

Programovací prostředí

Tento projekt byl realizován v programovacím prostředí LabVIEW 2009 zšířeném o speciální paletu funkcí určenou pro analýzu signálů (Advanced signal processing toolkit). Je nutné zmínit, že díky obsáhlosti a implementaci většiny použitých funkcí přímo v tomto prostředí, bylo možné tuto práci realizovat.

Výhoda vysoké rychlosti práce v tomto prostředí sebou nese úskalí v podobě omezené správy paměti počítače a nemožnosti editovat již implementované funkce na nejnižší úrovni.

Optimalizace kódu


Algoritmy byly prakticky vyzkoušeny na dvou-jádrovém procesoru. LabVIEW umožňuje velmi jednoduchým způsobem „donutit“ kompilátor pro optimalizaci kódu tak, aby byly použity obě jádra. Během návrhu a programování jsem tuto skutečnost nezohledňoval. Proto je možné, při lepší implementaci algoritmů dosáhnout se stejnou HW konfigurací až polovičních výpočetních časů pro zpracování jednotlivých průjezdů. Případně zvolit větší přesah časového okna pro obsáhlejší informaci o frekvenčním průběhu za účelem zlepšení funkce celého algoritmu.

6 DEMONSTRACE ALGORITMŮ

V této kapitole jsou demonstrovány jednotlivé kroky zpracování několika reálných signálů získaných při praktických měřeních, pomocí uvedeného měřicího kanálu. Pro odhad PSD je použita metoda MMV.

Příklad průběhu


Je detekováno vozidlo a zaznamenán vstupní signál, ten je následně podvzorkován na 2000Hz. Získáme tak například tento signál.



Obrázek 29 – průběh výstupního napětí mikrofonu v čase


Signál je asi 1,7s dlouhý. V době kdy se vozidlo blíží k mikrofonu (# 750 - # 1000) je z průběhu dobře čitelný šum způsobený rázy větru.

Je nalezeno PSD pomocí periodogramu.




Obrázek 30 – odhad PSD pro celý signál

Na základě tohoto odhadu je určeno frekvenční pásmo pro sledování dominantní spektrální složky.



Obrázek 31 – určení frekvenčního pásma na základě poměrového algoritmu


Určené pásmo je $\Delta f \in \langle 120; 172 \rangle \text{ Hz}$. Je vytvořena série PSD odpovídajících jednotlivým časovým oknům o délce 300 vzorků a přesahu 250 vzorků. Jsou nalezeny frekvenční špičky v pásmu Δf . Je tak získán průběh frekvenčních špiček a jejich amplitud v čase.



Obrázek 32 – výřez spektrogramu pro sledované frekvenční pásmo

Pozn.: spektrogram zde uvedený má přesah časového okna jen 13 vzorků pro lepší vyhlazení průběhu.

Pomocí algoritmu z Obrázek 27 je získán průběh dominantní spektrální složky. Následně jsou hledány parametry modelu, jehož výstup by takový průběh ideálně proložil. Je tak získána informace o rychlosti vozidla.



Obrázek 33 – nalezený frekvenční průběh a výstup hledaného modelu

Nalezené parametry:


Rychlost $v = 103,5 \text{ kmh}^{-1}$

Základní frekvence $f_0 = 141 \text{ Hz}$


Vzdálenost trajektorie vozidla od mikrofonu $s_{mic} = 3,75 \text{ m}$

Bod průběhu, kdy se vozidlo začalo vzdalovat $poz = 20,1$

Příklad průběhu




Obrázek 34 - průběh výstupního napětí mikrofonu v čase




Obrázek 35 - odhad PSD pro celý signál

Povšimněte si zcela odlišného PSD v porovnání s předchozím signálem. Jednalo se v obou případech o osobní vozidlo, pouze jiného typu.




Obrázek 36 - určení frekvenčního pásma na základě poměrového algoritmu

Určené pásmo je $\Delta f \in \langle 120; 175 \rangle \text{ Hz}$.



Obrázek 37 - výřez spektrogramu pro sledované frekvenční pásmo



Obrázek 38 - nalezený frekvenční průběh a výstup hledaného modelu

Nalezené parametry:

Rychlost $v = 83,4 \text{ kmh}^{-1}$

Základní frekvence $f_0 = 148 \text{ Hz}$


Vzdálenost trajektorie vozidla od mikrofonu $s_{mic} = 4,7 \text{ m}$

Bod průběhu, kdy se vozidlo začalo vzdalovat $poz = 17,1$

Pro oba uvedené průběhy, bylo vybráno frekvenční pásmo okolo $f_0 \approx 150 \text{ Hz}$.


Průvodcem takové hluku je pravděpodobně pohonné ústrojí vozu (motor, převodovka, zvuk z výfuku). Toto je nejvíce limitující faktor celé této navržené metody. Pokud by se takový systém zamýšlel použít v místě, kde se vozidla rozjíždí, respektive brzdí. Bude pak měření rychlosti velmi nepřesné. Tento fakt demonstruje následující průběh.

Příklad průběhu



Obrázek 39 – výřez spektrogramu průjezdu brzdícího vozidla

Vozidlo v místě měření brzdí. Navzdory pečlivému výběru měřicího místa při provádění experimentů, rovina několik set metrů na obě strany, byl toto relativně častý jev. Řidiči instinktivně „zvolní“ jakmile si všimnou obsluhy, která provádí měření v reflexní vestě.



Obrázek 40 - nalezený frekvenční průběh a výstup hledaného modelu

Nalezené parametry:

Rychlost $v = 166,1 \text{ kmh}^{-1}$

Základní frekvence $f_0 = 209 \text{ Hz}$


Vzdálenost trajektorie vozidla od mikrofону $s_{mic} = 12,1 \text{ m}$

Bod průběhu, kdy se vozidlo začalo vzdalovat $poz = 23$

Signál obsahoval dobře sledovatelnou frekvenci a výsledná odchylka proložení tak není příliš velká. I přesto, že rychlost $v = 166,1 \text{ kmh}^{-1}$ je možná. vzdálenost trajektorie vozidla od mikrofону $s_{mic} = 12,1 \text{ m}$ již možná není a na základě tohoto parametru se tak dá snadno rozhodnout, že odhadovaná rychlost je špatná.


Výše uvedené průběhy signálu byly pro „lepší situace“, kdy není PSD signálu příliš zatíženo šumem.

Spektrogram pro „horší situaci“ kdy fouká vítr a chod vozidla je kultivovanější vypadá následovně.



Obrázek 41 – kompletní spektrogram signálu

Ke stejnému signálu nalezený průběh frekvence a parametry modelu.



Obrázek 42 - nalezený frekvenční průběh a výstup hledaného modelu

Nalezené parametry:

Rychlost $v = 138,1 \text{ kmh}^{-1}$

Základní frekvence $f_0 = 201,2 \text{ Hz}$


Vzdálenost trajektorie vozidla od mikrofonu $s_{mic} = 3,5 \text{ m}$

Bod průběhu, kdy se vozidlo začalo vzdalovat $poz = 11,8$

Na tomto průběhu je dobře vidět, jak vychýlená hodnota frekvence pro časové okno #6 způsobila špatný odhad rychlosti vozidla. Vozidlo jelo pravděpodobně o několik Hz frekvenčního zdvihu pomaleji $v \approx 110 \text{ kmh}^{-1}$.

Poslední příklad průjezdu demonstruje neschopnost algoritmu určit rychlost pro rozjíždějící se vozidlo.


Příklad průběhu



Obrázek 43 – kompletní spektrogram vozidla, které se rozjíždí

Pro časová okna #60 - #80 je patrné přeřazení.



Vzhledem k rozložení výkonu do velmi širokého pásma tak algoritmus pro vyhledání optimální frekvence selže.



Obrázek 44 – PSD průjezdu a jeho ohodnocení z hlediska poměru výkonu

7 PROVEDENÁ MĚŘENÍ

Mimo měření uvedeného v kapitole 4.2, byly pro ověření navržené metody měření rychlosti provedeny dvě další dlouhodobé měření.



8 ZÁVĚR

Popsaná metoda akustické detekce a určení orientační rychlosti motorových vozidel prokázala, že lze získávat žádané parametry, které jsou využitelné při dopravních průzkumech a v dopravní telematice, tam kde z důvodů vysokých ekonomických nákladů nelze použít například stávající systémy sběru dat . Výsledné zařízení, jež nebylo cílem této práce, může být zpracováno ve formě do „all in one „ systému například na bázi ARM procesorů a umístováno podél dopravních komunikací v požadovaných místech.

Literatura

- [1] *Manuál LabVIEW*
- [2] *NIUSB 621x specifikace*, dostupné z: <http://www.ni.com/pdf/manuals/371932f.pdf>
- [3] *Fourier transform*, dostupné z: http://en.wikipedia.org/wiki/Fourier_transform
- [4] *Doppler effect*, dostupné z: http://en.wikipedia.org/wiki/Doppler_shift
- [5] R. Alty S., Benesty J., Jakobsson A. :*Efficient implementation of the local CAPON spectral estimate* [online], 15th European Signal Processing Conference (EUSIPCO 2007), Poznaň, 3.7. 2007
- [6] Bahler S., Kranig J., Minge E., *Field test of nonintrusive traffic detection technologie* [online] dostupné z:
<http://trb.metapress.com/content/u738347716x4007r/>, Minnesota Department of Transportation, Office of Advanced Transportation Systems, aktualizováno 23.1. 2007, ISSN 0361-1981
- [7] Rektorys K., kolektiv - *Přehled užití matematiky*, SNTL, třetí nezměněné vydání, kap.33-5, Praha, 1973.
- [8] Ahtola T. Olli - *Analysis of covariance, vol. 12*, ISBN – 9780803911642, 1978.
- [9] Angot A. - *Užitá matematika pro elektrotechnické inženýry*, strany 91 - 100 SNTL, Praha, 1960.
- [10] *Gibbs effect* [online], dostupné z : <http://www.dspguide.com/CH11.PDF>
- [11] *Window function*, html dostupné z http://en.wikipedia.org/wiki/Window_function
- [12] Oppenheim, Alan V.; Schafer, Ronald W.; Buck, John A - *Discrete-time signal processing*. Upper Saddle River, N.J.: Prentice Hall. strany 468–471. ISBN 0-13-754920-2.
- [13] Martin P., *Detector technology evaluation*, [online] dostupné z: Deptment of Civil and Enviromental engineering, University of Utah Traffic lab.

Seznam příloh

Příloha 1. Manuál ...

Příloha 2. Zdrojové texty ...

Příloha 3. CD/DVD ...

Tabulka použitých symbolů

Symbol	Význam
ψ_x	Efektivní hodnota veličiny x
x_i	Aktuální vzorek signálu